

Tekoäly lääketieteellisessä kuvantamisessa

Rintasyövän havainnointi mammografiakuvista

LuK-tutkielma
Eeva Nevanranta
Fysiikan tutkinto-ohjelma
Luonnontieteellinen tiedekunta
Oulun yliopisto 2021

Sisältö

Tiivistelmä

1. Johdanto

2. Rintasyöpä

2.1 Rinnan anatomia

2.2 Rintasyöpätyypit

2.3 Rintasyövän havainnointi

3. Rintojen kuvantaminen

3.1 Röntgenkuvauksen periaate

3.2 Mammografia

3.3 Tietokonetomografia

4. Tekoäly rintasyövän kuvantamisessa

4.1 Neuroverkot rintasyövän havainnoinnissa

4.1.1 Neuroverkon toimintaperiaate

4.1.2 Kuvien analysoiminen

4.2 Koneavusteinen diagnoosi

4.2.1 CAD:n haasteet

4.3 Tekoälyn soveltaminen CAD:iin

4.4 Neuroverkkojen haasteet

4.5 Neuroverkot ja mammografian eri kuvausmodaliteetit

5. Johtopäätökset

Tiivistelmä

Tässä LuK -tutkielmassa tutkittiin tekoälyn soveltamista radiologiaan käyttämällä mammografiaa esimerkkitapauksena. Rintasyöpä on naisten yleisin syöpä, sekä Suomessa, että muualla maailmalla. Rintasyövän ennuste kuolleisuuteen pienenee merkittävästi varhaisen toteamisen ja potilaskohtaisen hoidon myötä. Suomessa järjestetään rintasyövän seulontoja kahden vuoden välein, joissa kuvataan rinta röntgensäteilyyn perustuvalla mammografialaitteella. Mammografiatutkimuksia tulee suhteellisen tiheästä seulontavälistä johtuen suuri määrä, joka on johtanut valtavaan resurssipulaan radiologeista ympäri maailmaa. Resurssipulaan on tarjottu apua koneavusteisesta diagnoosista, jossa kone lukisi radiologin puolesta kuvat. Koneavusteinen diagnoosi on kuitenkin sisältänyt monia ongelmia kliinisessä käytössä.

2010-luvulla neuroverkot, ihmisen aivojen toimintaa jäljittelevät keinotekoiset mallit, tekivät läpimurron ja ovat kehittyneet tähän päivään asti merkittävästi. Kirjallisuuden perusteella voitiin havaita, että syväoppiminen on mahdollistanut huomattavan parannuksen perinteiseen koneavusteiseen diagnoosiin. Monet tutkimukset ovat yltäneet jo radiologien tasolle ja radiologien rinnalla toimiessa jopa parempiin tuloksiin.

Vaikka neuroverkkojen, sekä kehittyneiden koneavusteisten diagnoosien avulla on saatu kehitettyä yhä parempia ja luotettavampia ohjelmia, on niiden kliiniseen käyttöön ottamisessa edelleen ongelmia. Poliittiset ja eettiset kysymykset esimerkiksi hoitovirheiden sattua ovat ratkaisematta, syväoppimisen luotettavuus ei ole vielä täysin ratkennut ja käytännön järjestelyt uupuvat. Ongelmien ratketessa syväoppiminen voisi olla kuitenkin ratkaisu resurssipulaan, hoitovirheiden vähenemiseen, sekä mahdollistamaan potilaskohtaisemman hoidon.

Lyhenteiden ja merkkien selitykset

TT	Tietokonetomografia
CAD	Koneavusteinen diagnoosi
DBT	Digital breast tomosynthesis
R-LMO	Right mediolateral oblique
L-MLO	Left mediolateral oblique
R-CC	Right craniocaudal
L-CC	Left craniocaudal
h	Plankin vakio
ν	Taajuus
c	Valon nopeus
λ	Aallonpituus
μ	Absorptiokerroin
I	Intensiteetti
x_n	Sisääntulosignaali
w_k	Synaptinen paino
b_k	Neuronin vakiotermi
$\varphi(\bullet)$	Aktivaatiofunktio
y_k	Ulostulosignaali

1. Johdanto

Rintasyöpä on Suomessa naisten yleisin syöpämuoto jo 1960-luvulta lähtien. Keski-ikä taudin toteamiseen on 60 ikävuoden paikkeilla, mutta alkaa selkeästi yleistyä jo 45-vuotiaiden naisten keskuudessa. Rintasyöpä on yleistynyt jatkuvasti ja sen on ennustettu yleistyvän tulevaisuudessakin. [3] Syövän yleisyyden vuoksi Suomessa aloitettiin vuonna 1987 rintasyövän seulonta 2 vuoden välein, joka nykyään kohdistuu 50 - 69 vuotiaisiin naisiin.

Seulonta perustuu pääosin rintojen röntgentutkimuksiin, eli mammografiaan, jossa rinnat läpivalaistaan ja läpivalaisusta syntyy mammogrammi, eli läpivalaisukuva. Kuolleisuus on selkeästi pienentynyt seulontojen seurauksena ja on nykyään jopa 22 % pienempi, kuin ilman seulontoja. [1]

Rintasyöpä seulonta on tuonut mukanaan kuitenkin myös haittoja. Seulonnoissa tulee esille muun muassa myös pieniä kasvaimia, jotka eivät todennäköisesti olisi oireilleet naisen elinaikana. [1]


Radiologien mammogrammien lukutarkkuus on todella hyvä, mutta joukosta löytyy silti huomaamattomia syöpäkasvaimia, sekä vääriä positiivisia löydöksiä. Ongelmia on myös aiheuttanut radiologien resurssipula, sekä joka kolmannella terveeksi luokitetulla ilmenevä intervallisyöpä, jossa syöpäkasvain ilmaantuu seulontakertojen välillä. [10] Ongelmiin on koitettu etsiä ratkaisua koneavusteisen diagnoosin.

Yhdysvalloissa vuonna 1998 elintarvike- ja lääkevirastolta hyväksyi koneavusteiden diagnoosin mammografiaseulontojen käyttöön. Koneavusteisesta diagnoosista toivottiin ratkaisua mm. resurssiongelmiin, mutta se ei johtanut kuitenkaan tarkkuuden paranemiseen. Koneoppimisen kehityksen jatkuessa kehittyi monikerroksiset konvoluutiohermoverkot, joita on sovellettu myös mammogrammeihin, sekä DBT-kuviin. Tulokset ovat olleet lupaavia, mutta ongelmatonta ei vielä tekoälyn soveltaminen rintasyövän tutkimuksiin ole. [2]

2. Rintasyöpä

2.1 Rinnan anatomia

Rinta tyypillisesti ulottuu toisesta kylkiluusta ylemmäs aina kuudennen kylkiluuhun asti, sekä mediaalisesti rintalastan alaosaan ja lateraalaisesti keskisuuntaisen linjan kanssa. Rinnat sijoittuvat rintalihasten, sekä rintalastan päälle.



Kuva 1. Rinnan anatominen rakenne sivusta päin. Piirretty lähde [5], kuvaa 3a. mukailleen.

Kuvasta 1 nähdään rinnan anatominen rakenne. Rinta koostuu ihosta, ihonalaistakudoksesta, rintarauhasista, rintatiehyistä, nännistä sekä rasvakudoksesta. Rintojen koko, koostumus, sekä rasvan määrä vaihtelee yksilöittäin. Lisäksi esimerkiksi raskaus, imetys, sekä iäntuomat muutokset muuntavat rintoja. Nuorilla rinta on usein kiinteä ja koostuu pääpiirteittäin rintarauhasesta. Iän myötä rintojen rauhaskudos alkaa hajota muuttuen rasvaksi, jolloin rintojen tiheys heikkenee. [5]

2.2 Rintasyöpätyypit

Rintasyöpä luokitellaan kasvutapansa mukaan kahteen yleisempään tyyppiin, duktaaliseen karsinomaan, sekä lobulaariseen karsinomaan. Lisäksi harvinaisempia tyyppisiä on papillaarinen, medullaarinen, apokriininen ja adenokystinen karsinoma.

Duktaalisesta karsinoomasta (70 % rintasyövistä) on kaksi eri tyyppiä, invasiivinen eli leviävä ja intraduktaalinen eli tiehyensisäinen. Intraduktaalissa karsinoomassa, joka luetaan invasiivisen syövän esiasteeksi, eli duklaaisen in situ- karsinoomaksi, syöpäsolut kasvavat rauhastiehyeisen sisäpuolella. Se on mammografiassa usein selkeärajainen ja kasvain erottuu selkeästi rinnan muusta kudoksesta. Tämä usein huomataan diagnostiikan avulla jo mikrokalkkiumien johdosta varhaisessa vaiheessa.

Invasiivisessa syövässä puolestaan syöpäsolut kasvavat rauhaskudoksen läpi, joten niiden elo ei ole rajattua ja ne voivat lähettää etäpesäkkeitä. Mammogrammeissakaan ne eivät ole siten selkeärajaisia ja niiden radiologinen diagnostiikka on monissa tapauksissa vaikeaa.[3]

Lobulaarisessa karsinoomassa (10-20 % rintasyövistä) on tyypillistä infiltraatio peräkkäisten solujen muodostamina jonoina, sekä terveiden solujen säilyttäminen kasvaimen alueella.

Lobulaarinen karsinooma in situ on suurentunutta rintasyöpäriskiä ennustava muutos, joka havaitaan monissa tapauksissa lisälöydöksenä leikkauspreparaatista tai sattumalöydöksenä epäilyksiä herättäneen rintakyhmyn poistoleikkauksessa. [3]

Papillaarinen karsinooma saa tiehyiden sisällä aikaan papillaarisia rakenteita.

Medullaarisessa karsinoomassa kasvain näyttäytyy huonosti erilaistuneina sarakkeina, jotka rajoittuvat kasvainta ympäröivään rintarauhaseen.

Musinoottisessa karsinoomassa esiintyy runsaasti solun ulkopuoleista limaa.

Tubulaarisessa karsinoomassa kasvaimen alueella pienikokoisia säännöllisiä rauhasrakenteita. [1]

Fenotyyppin lisäksi voi rintasyövän erottaa myös sen genotyyppin mukaan. Yleisimmät genotyyppien alaryhmät ovat luminaalinen A, luminaalinen B, HER-2- ja basaalinen rintasyöpä.[3]

2.3 Rintasyövän havainnointi

Rintasyöpä voidaan havaita rinnasta tuntuvasta kyhmystä, ihon tai nännin vetäytymisestä sisäänpäin, sitkeästä ihottumasta, poikkeavasta nännieritteestä tai turvonneesta ja punaoittavasta rinnasta. Usein rintasyöpä havaitaan kuitenkin rintasyöpä seulonnoissa.

Pääosassa rinnan tutkimusta ja rintasyövän havainnoimista on mammografiaseulonnat, joihin Suomessa kutsutaan 50-69 vuotiaat naiset kahden vuoden välein. Mammografiaseulontojen avulla löydetään 40 % Suomessa todettavista rintasyövistä. Mammografia on röntgensäteilyyn perustuva kuvantamismenetelmä, mikä perustuu rinnan tiheyseroihin. Tiheyserot vaihtelevat kudostyyppin mukaan, rasvakudoksella on matalampi tiheys verrattuna rauhaskudokseen ja syöpäkasvaimella on useasti vielä suurempi tiheys, kuin rauhaskudoksella. Mammografian rinnalle on tullut myös tomosynteesi, ultraääni-, sekä kaikukuvaus.

Vaikeuden kuvantamiseen tekee rintojen tiiviit kudokset. Rauhaskudos, sekä sidekudos on tiivistä ja puolestaan rasvakudos näkyy mammogrammeissa läpikuultavana. Etenkin nuorilla naisilla, sekä esimerkiksi vaihdevuosikorvaushoidon läpikäyneillä naisilla voi olla rauhaskudosta paljon, jolloin mammografiakuvin syöpäkudokset saattavat jäädä piiloon tiiviiden kudosten taakse. Syöpäkasvaimet puolestaan ovat usein rauhaskudostakin tiheämpiä. Rinnan tiheys arvioidaan kuvantamisen avulla tiheys asteikolla, joka kulkee yhdestä neljään. Neljä asteikossa edustaa todella tiheää rintaa ja yksi puolestaan lähes täysin rasvaa.

Mammografiaseulonnan sensitiivisyys on 92 % luokkaa ja spesifisyys 97 % luokkaa. Toisaalta kahden vuoden välein tehtävien seulontojen välillä jopa kolmasosalle seulontaan osallistuneista ilmaantuu syöpä. Näistä seulontasyöivistä, sekä välisyöivistä harva johtaa rintasyöpäkuolemaan. [3] Mammografiaseulontojen on osoitettu pienentävän kuolleisuutta vähintään noin kolmannekselle seulontaan osallistuneilta. [6]

Uusien kuvaustekniikoiden (kaiku- magneettikuvaus, tomosynteesi) parantamista tuloksia (herkkyys ja tarkkuus) tutkitaan ja nykyäänkin niitä käytetään mammografian rinnalla lisätutkimuksina tai, jos mammografiasta ei saa tarvittavia tuloksia.

Seulonnessa esiintyy myös resurssipulaa. Radiologeja ei ole tarpeeksi ja radiologien erikoistumiskoulutuksessa ei välttämättä saa opetusta mammografiaseulontoihin ollenkaan. [7] Lisäksi seulonnassa käytetään kaksoisluentaa eli kahden röntgenlääkärin on luettava kuvat toisistaan riippumattomina (STM asetus 423/2000 41§). Mammografiaseulonnat eivät koostu pelkästä neljästä seulontakuvasta vaan monen tapahtuman ketju. Kuvien lukeminen ja diagnoosin koostaminen niistä vie radiologilta paljon aikaa, joten on ehdotettu, että tekoälystä löydetäisiin resurssipulaan, sekä tuloksien sensitiivisyyteen parannusta.


3. Rintojen kuvantaminen

Rintojen kuvantamisessa käytetyin menetelmä on mammografia, mutta myös tietokonetomografia, ultraäänitutkimus, magneettikuvaus, galaktografia, sekä isotooppikuvaus ovat käytössä. [9]

Mammogrammien antaessa liian vähän tietoa, tarvitaan lisätutkimuksia. Lisätutkimuksia on usein kätevää tehdä tietokonetomografian, eli TT:n avulla, sillä kuvien vertailu on suhteellisen helppoa niiden näyttäessä hyvin samantyyllisiltä. Tomografian avulla on kuitenkin mahdollista saada viipalekuvien avulla 3D mallinnus rinnasta, mammografian antaessa vain yksittäisiä 2D kuvia. Mammografia, sekä tietokonetomografia perustuu röntgensäteilyyn.

3.1 Röntgenkuvauksen periaate

Röntgensäteily on ionisoivaa säteilyä, eli sähkömagneettista säteilyä, jolla on väliaineeseen törmätessään tarpeeksi energiaa ionisoida sitä. Kuvantamisessa ei ole tarvittavaa ionisoida kuvattavaa ainetta, mutta säteilyn täytyy päästä kuvattavasta aineesta läpi, jotta projektiokuva voi muodostua, eikä pienempi energiamäärä tähän pysty.




Kuva 2. Röntgenputken rakenne. Piirretty lähde [4], kuvaa 1.4 mukaillen.

Röntgenputkessa on kuumennettu hehkulanka, joka emittoi elektroneja. Jännite (10-150kV) kiihdyttää ne, jolloin ne sinkoutuvat anodiin. Elektronit törmätessään anodiin hidastuvat voimakkaasti. Suurin osa jarruuntuvien elektronien energiasta (99 %) muuntuu lämpöenergiaksi, sekä valoksi, mutta lopusta (1 %) syntyy röntgensäteilyä. Syntyneet fotonit pyritään ohjaamaan röntgenputken säteilyikkunaa kohti. Röntgenkuvauksessa käytetään lyhytaaltoista 0.01-10nm pituista sähkömagneettista säteilyä kuvanmuodostukseen. Fotonin energia määräytyy kaavalla

$$E = h\nu = \frac{hc}{\lambda}.$$

Röntgenputken sivussa on ”ikkuna”, josta muodostunut säteily ohjautuu ulos anodilautasen ollessa sopivasti vinossa.



Kuva 3. Röntgenkuvantamislaitteen rakenne. Piirretty lähteen [12] kuvaa 1 mukaillen.

Röntgenputkessa muodostunut säteily suodatetaan, jotta jäljelle jää vain haluttu energiset fotonit. Tämän jälkeen säteily kulkee hilan läpi, joka rajaa pois väärasuuntaiset fotonit. Jäljelle jääneet fotonit kulkeutuvat kuvauskohtaan.

Kuvan luominen röntgensäteilyn avulla perustuu kuvatus kohteen vaihteleville tiheyksille ja niiden säteilyn absorbointiin. Kehon eri osat vaimentavat säteilyä seuraavan kaavan mukaisesti.

$$I = I_0 \cdot e^{-\mu \cdot d}.$$

Kaavassa I on detektorille saapuvan säteilyn intensiteetti, I_0 alkuperäinen, säteilylähteeltä lähteneen säteilyn intensiteetti, μ kudoksen absorptiokerroin ja d kudoksen paksuus, jonka säteily läpäisee.

Luukudos absorboi röntgensäteilyä huomattavasti enemmän, kuin esimerkiksi rasvakudos ja ilmaa täynnä olevat keuhkot puolestaan eivät absorboi säteilyä juuri

ollenkaan. Tämä johtuu siitä, että luu on tiheämpää, kuin rasva tai keuhkojen ilmatäyte, jolloin säteily vaimenee sen vaikutuksesta enemmän.

Kudosten tiheyserot näkyvät kontrastieroina röntgenkuvissa. Säteilyä voimakkaasti absorboiva, kudoks näkyy valkoisena ja pienemmän absorptiokertoimen omaava kudoks näkyy tummana. Mitä parempi eri tiheyksien erottuvuus, eli kontrasti halutaan, sitä pienempää jännitettä on käytettävä. Ionisoivaa säteilyä käytettäessä täytyy kuitenkin tehdä kompromisseja sädeannosten ja tuloksien tarkkuuksien kanssa, sillä matala jännite lisää potilaan sädeannosta, jolloin on etsittävä käytettävä jännite kuvattavan kudoksen mukaan huomioiden potilaaseen kohdistuva säteilyannos. [12]


3.2 Mammografia

Mammografia on röntgenkuvantamiseen perustuva tutkimusmenetelmä, jossa laitteisto on kehitetty rintojen kuvantamiseen. Laitteessa käytetään molybdeeni-, rodium-, tai volframianodia, sekä molybdeeni-, rodium-, tai volframisuodatusta. Kuvauksessa on käytössä pieni (25-30kV) kuvausjännite, suuri kuvausvirta, liikkuvaa hilaa, sekä lyhyttä kuvausaikaa. Näin kuvantaminen optimoidaan pehmytkudoksien tiheyserojen selvitykseen. Kuvauksessa on käytössä myös pieni fokuskoko, joka mahdollistaa hyvän paikanerotuskyvyn, jotta pienetkin yksityiskohdat saadaan erotettua toisistaan.

Mammografialaite koostuu siis röntgensäteilyä tuottavasta röntgenputkesta, säteilyn suodattuksesta, kaihtimesta, muovilevystä, sekä kuvailmaisimesta. Rinta puristetaan muovilevyn ja kuvailmaisimen väliin hajasäteilyn vähentämiseksi, jolloin kuvaan saadaan parempi kontrasti, sekä tarkkuus, kun kuvattavan kohteen ja ilmaisimen välinen etäisyys on pienempi.

Mammografiaperuskuvat muodostuvat kahdesta eri kuvausprojektista, viistokuvauksesta eli mediolateraalikuvauksesta, sekä kraniokaudaalikuvauksesta. Viistokuvauksessa saadaan kuva koko rinnasta, sekä osasta kainaloa, kun röntgenputkea kallistetaan 60 asteen kulmassa. Kraniokaudaalikuvauksessa kuva muodostuu rinnan aksiaalisuunnassa, kun röntgensäteet tulevat suoraan ylhäältä päin. Kraniokaudaalikuvassa näkyy rinnan rauhaskudoksen mediaali-, sekä lateraalireuna, sekä rauhaskudoksen takana oleva rasvakerros. Lisäkuvia voidaan ottaa valituista suunnista olettavat kohdesuurennoskuvat. [8]

Mammografian ongelmana on tiheän rintarauhaskudoksen peittämät syöpäkasvaimet. [7] Eri suunnista otetut projektiot kuitenkin pienentävät tiheiden rintarauhasten taakse jääneiden huomaamattomaksi rintasyöpäkasvaimien riskiä.




KUVA 4. Esimerkkikuvia mammogrammien projektioista. (Courtesy of Breast Research Group, INESC Porto, Portugal)

Kuvasta 4 nähdään esimerkkitapauksia yhden henkilön mammogrammeista. Yleisimmät projektiot ovat kuvista nähtävissä vasemmalta oikealle R-MLO, L-MLO, R-CC ja L-CC. Ensimmäinen ja toinen vasemmalta ovat kraniokaudaalikuvia (CC) ja puolestaan kolmas ja neljäs vasemmalta mediolateraalisuunnasta (MLO) otettuja kuvia. R ja L projektiokuvissa kuvaa vasenta (L) tai oikeaa (R) rintaa. Rinnan tiheys on 2.

3.3 Tietokonetomografia

Tomografia kuvauksella saadaan rinnasta viipalekuvaus, joka ratkaisee usein mammografian päällekkäisyysongelman. Kuvauksessa röntgenputki, sekä sen vastakkaisella puolella oleva ilmaisin kiertävät ympäri kohdetta ympyräradalla.



Kuva 5. Tietokonetomografiakuvaus järjestely. Piirretty lähteen [12] kuvaa 6 mukaillen.

Röntgenputki lähettää säteilyä, joka päätyy siis potilaan läpi ilmaisimeen. Ilmaisimessa säteilyn intensiteetistä voidaan määrittää vaimenemisprofiili. Yhden pyörähdysten aikana määritellään satoja vaimenemisprofiileja eri puolilta kohdetta. Fotonikeila, jonka röntgensäteilylähde säteilyttää, vaimenee kudosten vaimenemiskertoimien mukaan. TT -kuvauksessa on kudoksen vaimeneminen määritetty HU-arvolla, joka on riippumaton säteilyn energiasta. Kudoksen HU arvo saadaan kaavalla

$$HU_{kudos} = 1000 \cdot \frac{\mu_{kudos} - \mu_{vesi}}{\mu_{vesi}}.$$

Kaavassa μ_{kudos} on kudoksen absorptiokerroin, ja μ_{vesi} on veden absorptiokerroin. Absorptiokerroin saadaan johdettua säteilyn vaimenemisen kaavasta, joka on kappaleessa 3.1, jolloin

$$\mu = \ln\left(\frac{I_0}{I}\right) \cdot \frac{1}{d}.$$

Matemaattisen takaisinprojektion mukaan erisuunnista tulevat vaimenemisprofiilit alipäästösuodatetaan, jonka jälkeen niistä muodostetaan kuvamatriisi. Lopullisesta kuvasta tulee vaimenemisprofiilien sisältämän informaation mukaan leikekuvien avulla kolmiulotteinen mallinnus. [12]

Tomografiatutkimuksen suurena etuna on mahdollisuus asetella potilas samoin, kuin mammografiassa, jolloin löydösten tutkiminen helpottuu. Tomografia ei ole kuitenkaan yhtä yleinen, kuin mammografiakuvaus, mutta se toimii monessa paikassa mammografian jatkotutkimuksena epäselville tilanteille. [8]

On todettu, että rintojen tomosynteesillä löytyy noin 30-40% enemmän syöpiä, kuin mammografialla. Mammografiaan verrattuna tomografian kuvantamisten tutkiminen vie kuitenkin enemmän aikaa, ja kuvauksista tehdyt johtopäätökset sisältävät edelleen virheitä. [2]


4. Tekoäly rintasyövän tutkimisessa

Tekoälyllä tarkoitetaan tietokoneohjelmaa tai sovellusta, joka pyrkii jäljittelemään ihmiselle ominaista älykästä toimintaa, kuten ongelmien ratkaisua tai päätöksentekoa matemaattisin mallein. Tekoälyyn läheisesti liittyviä käsitteitä ovat esimerkiksi neuroverkot, syväoppiminen, koneoppimien ja konenäkö. Nykyään tekoäly yhdistetään kuitenkin pitkälti syväoppimiseen, sekä neuroverkkoihin. Tekoälyn kehitys alkoi jo 1950-luvulla, mutta isona ongelmana oli tietokoneiden kyvyttömyys käsitellä niin suuria datamääriä, mitä tekoälyn kehittäminen vaatii. Tekniikkojen, sekä ymmärryksen parantuessa, 2010-luvulla neuroverkot tekivät läpimurron. Tästä kehityksestä on hyötynyt moni ala, mukaan lukien lääketiede ja rintasyövän tutkimus. Koneelle voitaisiin näin kerrasta opettaa tunnistamaan syöpiä, jolloin inhimilliset virheet vähenisivät, tarkkuus paranisi, väärät diagnoosit vähenisivät, sekä resurssipula helpottaisi. Rintasyövän tutkimiseen on kehitetty niin koneavusteiseen diagnoosiin, kuin syviin konvoluutioverkkoihin pohjautuvaa tekoälyä. [9,12]

4.1 Neuroverkot rintasyövän havainnoinnissa

4.1.1 Neuroverkon toimintaperiaate

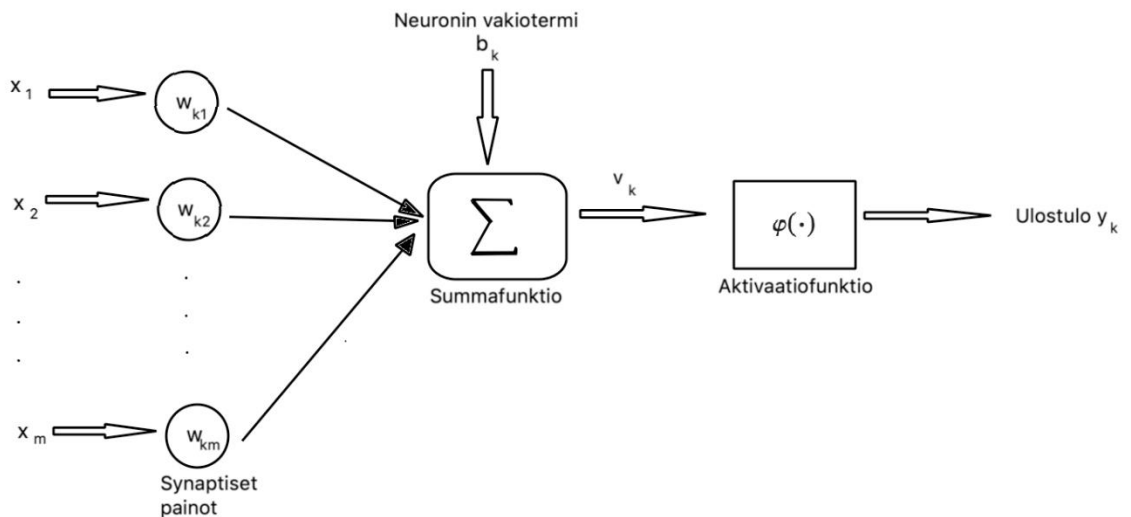
Neuroverkot pyrkivät jäljittelemään ihmisen aivojen toimintaa, jossa tietoa käsittelevät ”solmut” kykenevät kommunikoimaan toistensa kanssa.



Kuva 6. Mallinnus yksinkertaisesta neuroverkosta.

Neuroverkot koostuvat syötekerroksesta, piilokerroksista, sekä ulostulokerroksesta. Kuvassa 5 näemme yksinkertaistetun neuroverkon rakenteen, jossa O-symbolit esittävät neuroneita ja viivat neuroneiden välisiä yhteyksiä, jotka jäljittelevät synapseja, kahden neuronin välisiä kytkentöjä.

Neuronit ovat neuroverkon tiedonkäsittelyn yksiköitä. Niihin kulkeutuu syötekerroksesta tieto, jonka ne käsittelevät niille annetun opetusdatan perusteella. Piilokerroksen neuroniin kulkeutuu kuvan 6 mukaisesti kaikilta syötekerroksen neuroneilta tai syvemmissä neuroverkoissa vastaavasti edellisen kerroksen neuroneista. Tätä tietoa kuvataan sisääntulosignaalin x .



Kuva 7. Yksittäisen neuronin toimintakuvaus. Piirretty lähteen [16] kuvaa 7 mukailleen.

Kuvasta 7 nähdään neuronin toiminnan periaate, josta puhutaan nimellä perceptron. Perceptroni kuvaa yksittäisen neuronin toimintaa tulosignaalin vaikutuksesta. Nyt x_1, x_2, \dots, x_m on sisääntulo signaali, joka saapuu neuroniin. Synaptiset painot $w_{k1}, w_{k2}, \dots, w_{km}$ kuvaavat tiettyjen neuronien välistien yhteyksien ominaista painokerrointa tai


vahvuutta. Synaptisten painojen alaindeksi k viittaa kyseessä olevaan neuroniin ja alaindeksit $1, 2, \dots, m$ arvot synapsin tulopäähän. b_k kuvaa neuronin vakiotermiä ja summafunktio koostaa kaikki edellä mainitut muuttujat yhteen. Aktivointifunktio rajaa ulostulon leveyttä rajoittaen lähtösignaalin amplitudialueen rajallisiksi arvoiksi. Nyt siis neuronista lähtee ulostulosignaali

$$y_k = \varphi(u_k + b_k),$$

jossa

$$u_k = \sum_{j=1}^m w_{kj} x_j.$$

Yksinkertaisin aktivointifunktio on kynnysfunktio.



Kuva 8. Kynnysfunktion kuvaaja. Hahmoteltu lähteen [16] kuvaa 8a. mukaillen.

Kynnysfunktio ilmaisee hermosolun k ulostulon


$$y_k = \begin{cases} 1, & \text{kun } v_k \geq 0 \\ 0, & \text{kun } v_k < 0 \end{cases}$$

Neuronin ulostulofunktio saa siis vain arvoja nolla tai yksi riippuen, onko paikallinen kenttä negatiivinen vai positiivinen.

Aktivointifunktio ilmaisee neuronin ulostulon indusoidun paikallisen kentän v avulla, kun

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k.$$

Yleenä vain 0 ja 1 arvojen saaminen ei riitä, vaan tarvitaan arvoja myös väliltä 0 ja 1, sekä toisinaan myös väliltä -1 ja 1. Syväoppimisessa käytetyimmät aktivaatiofunktiot ovat sigmoidi, hyperbolinen tangentti (tanh), sekä ReLU (Rectified linear unit).



Kuva 9a. ja 9b. Kuvissa Näemme vasemmalla ReLU -funktion kuvaajan ja oikealla sinisellä Sigmoid -funktion kuvaajan, sekä punaisella Tanh -funktion kuvaajan. [17]

Kynnysfunktio ei ole differentioituva, joka on neuroverkkojen ja syväoppimisen tapauksessa hyödyllistä. Sigmoidi, sekä tanh funktiot ovat differentioituvia ja ReLU funktio on differentioituva nollasta eteenpäin. Sigmoidi ja tanh funktioiden arvoalue on välillä $[0, 1]$, sekä $[-1, 1]$, joka pakottaa siis arvot asettumaan tälle välille.

Aktivaatiefunktion avulla ulostulofunktio y_k kulkee verkossa edelleen uuteen neuronin ja siihen vaikuttaa taas uusi synaptinen painokerroin. Lopulta signaalit kulkeutuvat ulostulokerrokseen, jossa saamme halutun tuloksen.[16]

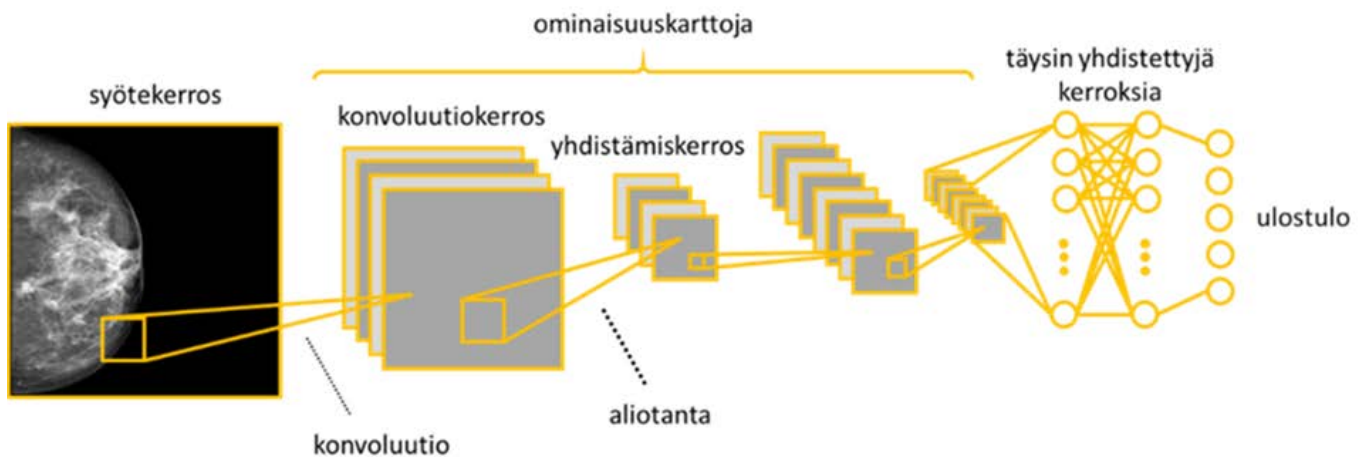
Jotta neuroverkko voi toimia, täytyy se kouluttaa. Rintasyöpää havainnoiva neuroverkko koulutetaan usein back propagation tekniikalla, joka perustuu neuroverkon painoarvojen gradientin pienenemiselle neuroverkossa. Tässä on tärkeä osa aktivaatiefunktion differentioituvuudella, sillä kynnysfunktioilla tämä ei onnistuisi. Back propagation menetelmässä lasketaan vektorin w ominaisuuksista annetun x arvolle tehokkaasti osittaisderivaattoja. Painokertoimen w elementit ovat alun alkaen kerroksen määräämiä, sitten neuronin ja lopuksi neuronin synapsin.

Verkon koulutus aloitetaan alustuksella, jossa synaptisille painoille ja kynnysarvoille annetaan arvot tasaisesta jakaumasta, jonka keskiarvoksi saamme nollan. Varianssi määrätään niin, että neuronien aiheuttamien paikallisten kenttien keskihajonta olisi sigmoidiaktiivointifunktion lineaaristen ja standardiosien välissä. Tämän jälkeen verkolle esitetään koulutusesimerkit, joiden eteen, sekä takaisinkytkennän ketjut tunnetaan. Tämän jälkeen verkko kytkeytyy eteenpäin, jolloin tulovektori kohdistetaan tulokerrokseen ja haluttu vastevektori esitetään laskennan tulokerrokselle. Verkon aiheuttamat paikalliset kentät saa siten laskettua kerroskerrokselta. Tämän jälkeen verkko takaisinkytketään, jolloin saadaan laskettua verkon paikalliset gradientit. Eteen- ja takaisinkytkentää vuorotellaan, kunnes verkolle määritelty pysäytyskriteeri täyttyy, eli päästään haluttuun lopputulokseen.

[16]

4.1.2 Kuvien analysoiminen

Neuroverkkojen etuna on kyky oppia datanvälisiä abstrakteja esityksiä ennen koko kuvan luokittelua. Se pystyy yhdistelemään toisiaan lähellä olevien vokselien eli pikselien kolmiulotteisten vastineiden tietoa, jolloin se soveltuu hyvin kuvien analysoimiseen.



Kuva 7. Konvoluutioneuroverkon periaatekuva. (Mammogram Courtesy of Breast Research Group, INESC Porto, Portugal) Copyright CC BY ND Antti Isosalo.

Mammogrammien käsittelyssä tarvitaan kuva-analyysiä, joka perustuu hyvin monissa tapauksissa konvoluutiverkkoon. Se koostuu monikerroksista perceptroni kerroksista muodostaen konvoluutioverkon, mikä soveltuu hyvin mallien luokitteluun, erityisesti kaksiulotteisiin muotoihin. Se poimii kuvan ominaisuuksia, jonka jälkeen ne kulkevat verkossa neuronilta neuronille. Tämä johtaa ominaisuuden paikkafunktion heikkenemiseen, mutta säilyttää oleellisen, eli sijainti suhteessa muihin ominaisuuksiin säilyy. Kuva käydään konvoluutiokerrosten avulla pikseli pikseliltä läpi. Tässä siis jokaisessa ominaisuuskartassa on tietty ominaisuus, jota ominaisuuskartta havainnoi. Ominaisuuskarttaa voidaan ajatella maskina, joka on esimerkiksi neljä kertaa neljä pikselin kokoinen, jonka avulla kuva käydään järjestelmällisesti läpi. Aliotannan ansiosta jokaiselta maskin läpikäyneeltä paikalta jää suurin arvo voimaan. Tämän ansiosta laskennan määrä vähenee tulevissa kerroksissa, mutta ominaisuuksien määrä säilyy, sekä sijainti toisiinsa nähden säilyy.

Ominaisuuskarttojen jälkeen tiedot siirtyvät perceptron -verkon tyyppisen täysin kytkettyjen kerrosten käsittelyyn, joka käsiteltiin edellisessä luvussa (katso kohta 4.1.1.). Tästä tiedot siirtyvät ulostulo kerrokseen.

Konvoluution kaikki painoarvot ovat tulosta verkon koulutuksesta ja oppimisesta. [16]

Neuroverkot koulutetaan CAD:in tavoin, jossa jokaisella ohjelmalle annetulla esimerkillä pyritään odotettuun lopputulokseen. Koulutus tehdään esimerkitapauksien avulla, jonka lopputulos tiedetään. Toistojen ja monien

esimerkkien avulla verkko oppii tunnistamaan halutun ominaisuuden. Käytössä on siis ohjattu oppiminen.

Neuroverkot koulutetaan usein havaitsemaan vain yhtä ominaisuutta, esimerkiksi rintasyöpien tapauksessa massoja tai kalkkeutumia. Tämän jälkeen ne yhdistetään yhdeksi asiantuntijajärjestelmäksi. [12]

4.2 Koneavusteinen diagnoosi

CAD eli koneavusteinen diagnoosi on yksi merkittävimpiä rintasyövän havainnoinnin työkaluja. CAD:n kehitys syöpätutkimukseen on aloitettu jo 1960-luvulla, jolloin sen pääasiallinen tarkoitus oli huomata hienovaraiset syövät, joka jäisi radiologeilta huomaamatta.

Syöpien havainnointi CAD:lla perustuu lisääntyneen tiheyden ja mikrolaskelmien (engl. microcalcifications) painopistealueiden merkitsemiseen. Mikrolaskenta tarkoittaa pieniä kalsium kerrostumia, jotka mammografiakuvin näkyvät valkoisina pisteinä. Ne voivat olla ryhmittyneinä yhteen tietyssä muodoissa merkki varhaisesta rintasyövästä tai syöpäsoluista.

CAD tekee radiologille mahdollisista poikkeamista ehdotukset ja kykenee hyvin huomaamattomien poikkeavuuksien havaitsemiseen ja parantaa siten syöpien havaitsemisastetta. Tämä kuitenkin johtaa myös 6-36% suurentuneeseen palautusasteeseen ja siten työmäärän kasvuun, sekä arviointiaikojen pidentymiseen.

CAD:n suoritus riippuu ihmisen sille suunnitelluista ominaisuuksista. Pääpiirteittäin CAD luokitellaan kuitenkin kahteen ryhmään; tunnistusjärjestelmiin, sekä diagnosijärjestelmiin. Tunnistusjärjestelmät havainnoivat epäilyttävän poikkeavuuden kuvan harmaatasoissa. Poikkeavuus voi perustua massan havainnointiin, eli kuvan valkoiseen väriin, löydöksen tekstuuriin, eli siihen onko tekstuuri homogeeninen vai ei, epäilyttävään muotoon, sekä mikrolaskennalliseen sauvamaisen korkean intensiteetin omaaviin pikseleihin mammogrammissa. Tämän jälkeen yhdistetään erottuvimmat piirteet kuvasta, jonka perusteella ohjelma tekee päätöksen, katsotaan ylittävätkö löydetty poikkeavuudet kynnyksen vai ei. Päätökset lukee radiologi. Diagnosijärjestelmät puolestaan tekevät poikkeavat havainnot mammogrammista tunnistusjärjestelmän tyyliin, mutta arvioivat myös löydökset hyvä-, sekä pahalaatuisiksi todennäköisyyden perusteella. Tämän jälkeen radiologi päättää lisäarvioinnin tarpeesta. Tavanomaiset CAD-järjestelmät siis esittävät havaintonsa kehoitteilla poikkeamista mammografiassa, jolloin lopullinen päätös jää ihmiselle. [2]

4.2.1 CAD:n haasteet

CAD omaa monta hyvää piirrettä, mutta siinä on myös paljon korjattavaa, jonka vuoksi se ei ole soveltunut luotettavaksi mammogrammien tulkitsijaksi poistaen siten esimerkiksi resurssipulaa. CAD toimii pääasiassa kehoitteilla, joita radiologi tulkitsee. Pahimmillaan kehoitteita saattaa tulla yli 1000 yhtä uutta syöpää kohden, jolloin

lukuajat pidentyvät entisestään. Lisäksi vaikka se on lisännyt havaitsemisastetta, on sillä huomattavasti matalampi spesifisyys, kun palautusaste on lisääntynyt jopa 6-36%. Kliinisessä käytössä ei ole todettu CAD:in parantavan diagnostista tarkkuutta. Se tekee paljon vääriä kehotteita, jotka lisää vääriä positiivisia diagnooseja. Lisäksi kehotusten yksi iso ongelma on epäselvyys. Kaikkien kehitettyjen CAD-ohjelmien kehoteet ovat erilaiset, jolloin kehotteen tulkinnassakin saattaa kulua turhaa aikaa ja kehotuksien tarkoitus saattaa jäädä ymmärtämättä.

CAD:n parhaita tuloksia tuonut malli, joka perustuu rintakudoksen tiheyden arviointiin, sisältää myös epäkohtia. Tällaisissa tapauksissa tiheä rintarauhaskudos saattaa jättää syövän taakseen ja näin estää sen havainnoinnin. Rintojen tiheysarviointi on kuitenkin CAD:lla ihmiseen verrattuna johdonmukaisempi, mutta ennustaessa rintasyövän mahdollisuutta on CAD järjestelmä radiologia heikempi. Toisaalta jos järjestelmään sisällytetään massalaskennan lisäksi tekstuuriominaisuus, paranee riskiennustaminen.

4.3 *Tekoälyn soveltaminen CAD:iin*

CAD:n parantamiseen on ehdotettu soveltaa koneoppimisen viimeaikaiseen kehityksen tulosta, joka perustuu monikerroksisten neuroverkkojen kehittelyyn.

Neuroverkkojen etuna on vokseleiden, eli pikseleiden kolmiulotteisten vastineiden yhteyksien luominen. Hermoverkot pystyvät yhdistämään lähekkäin olevien vokseleiden tietoja ja oppimaan datan välisiä abstraktimpia esityksiä ennen koko kuvan luokittelua. Tämä on mammogrammien yhteydessä iso etu.

Neuroverkot ovat spesifisimpiä kuin CAD, ne pystyvät tunnistamaan paremmin hyvälaatuiset ja pahalaatuiset kasvaimet. Tämän avulla on onnistuttu vähentämään väärien positiivisten määrää ja palautusprosentti on alentunut jopa 20%.

Rintasyöpien havainnoimisessa neuroverkot antavat vähemmän vääriä positiivisia löydöksiä kuin perinteinen CAD. Tekoälyn etuna on lisäksi lukijalle annettava palaute myös niistä kohdista, joita se ei pidä tarpeeksi poikkeavina varsinaiseen kehotteen antamiseen. Tekoäly kykenee myös mammografiakuvissa vaadittuun kaksoisluentaan [2], joka helpottaisi merkittävästi resurssipulaa. Tähän päästäkseen täytyy kuitenkin normaalia eli tervettä tapausta vahvistaa verkolle. Vahvistamisessa verkolle opetetaan yhä useampia terveitä tapauksia, jotta se tunnistaisi paremmin terveet tapaukset syöivistä, eikä vääriä positiivisia tuloksia tulisi siten niin paljoa.

Neuroverkot voivat toimia myös CAD:n tyylisen järjestelmän kanssa yhteistyössä, jolloin ensimmäisessä vaiheessa CAD osoittaa poikkeavuudet lisääntyneen tiheyden ja mikrolaskennan painopistealueiden avulla ja tekee niistä ehdotuksen tai ”lämpökartan” lukijalle. Hybridijärjestelmissä puolestaan tekoäly lisäksi ohjaa ihmislukijaa todennäköisimpiin valintoihin, jolloin lukijan suorituskyky valita oikea poikkeavuus kuvasta kasvaa.

CAD- järjestelmät ovat neuroverkkojen avulla kehittyneet paljon ja ne yltyvät nykyään radiologien suorituskyvyn tasolle tunnistessa rintasyöpiä, mikäli käytetään ominaisuusperusteista luokitusta, kuten massan perusteella arvioiminen. Ne myös

osoittavat tapauskohtaiset todennäköisyydet syöpään, joka helpottaa ja nopeuttaa radiologien kuvien lukua. [2]

On ehdotettu, että ihmisen kaltaista tekoälyjärjestelmää käytettäisiin ihmislukijan rinnalla, eli kaksoisluku periaatteen mukaan tutkittaisiin kuvat edelleen, mutta toisena lukijana olisi tekoäly. Kolmas osapuoli ratkaisisi tilanteen, joissa tekoälyn ja ihmislukijan tekemä arvio eroaa. Näin työmäärä edelleen vähenisi, mutta tällaisen systeemin todellista vaikutusta ei vielä tunneta. [2]

Taulukko 1. Muutamia mammografia-aiheisia töitä ja niiden suorituskykyarvoja [13, 14, 15]

Tutkimus	Algoritmi	Opetusdata	Tulokset
Wu et al. 2017. [13]	Syväoppimiseen perustuva tiheysluokittelu	Yli 200 000 syöpätutkimusta, 1 000 000 kuvaa	Tavoitti saman tulkintatason, mikä radiologeilla oli toistensa kanssa
Wu et al. 2019. [14]	Konvoluutioverkkoihin perustuva rintasyövän luokittelija	Yli 200 000 syöpätutkimusta, 1 000 000 kuvaa	AUC 0,895 Keskimääräinen pahalaatuisuuden ennuste radiologin kanssa kaksoisluntana parempi, kuin kumpikaan erikseen.
Yala et al. 2021. [15]	Syväoppimiseen perustuva rintasyövän riskin ennustaja, ottaa huomioon myös riskitekijät, kuten ikä ja hormonaaliset tekijät	Yli 70 000 syöpätutkimusta, joista kaikissa 4 eri projektia	AUC vaihteli 0,78-0,9 Tunnisti lähes kaksi kertaa enemmän syöpiä verrattuna nykyiseen kliiniseen standardiin. Aiempia malleja tarkempi ennustaessa ja tunnistaessa syöpiä.

Neuroverkot ovat kehittyneet tehokkaammaksi tavaksi CAD:iin verrattuna, mutta sisältävät ongelmia kuitenkin kliiniseen käyttöön soveltuakseen. Testitulokset paranevat koko ajan tiedon lisääntyessä ja opetusdatan kasvussa, mutta myös uusien koulutustietojen soveltamisessa.

Yala et al. tutkimuksessa on kehitetty rintasyövän riskiin perustuva ohjelma, joka osaa huomioida päätöksissä myös potilaan riskitekijät. Yalan malli ennustaa potilaalle riskin sairastua rintasyöpään seuraavan viiden vuoden aikana. Malli saavutti merkittävästi aikaisempia malleja paremman tarkkuuden syöpäriskien ennustuksessa, sekä korkean syöpäriskin omaavien potilaiden tunnistuksessa. Yalan malli toimi samoin riippumatta potilaan genetiikasta, iästä tai rintojen tiheysluokasta. Tämän kaltaiset mallit mahdollistavat potilaskohtaiset seulontasuunnitelmat ja aikaisemman syövän havainnoinnin parantaen siten potilaan ennustetta ja vähentäen seulontahaittoja. [18] Riskiennustus on merkittävä tekijä radiologien päätöksessä, mutta riskitekijät eivät ole ennen olleet mukana CAD:n tai neuroverkkojen päätöksen teossa, sekä opetusdatassa

onnistuneesti. CAD:iin on yritetty soveltaa aikaisemmin riskimalleja, mutta niiden teho on ollut vaatimaton. [15]

4.4 *Neuroverkkojen haasteet*

Kaikilla syväoppimisen malleilla, myös neuroverkoilla on tiedonkeruu todella työlästä ja suoritustapa riippuu vahvasti radiologien tekoälymenetelmää varten tekemien annotointien laadusta. Suurena ongelmana tässä kuitenkin on se, ettei perustotuutta ole, jolloin eri radiologien annotoinnit voivat vaihdella samankin tapauksen kohdalla. Koulutuksessa käytetty ohjattu oppiminen toimii neuroverkkojen tapauksessa vain, jos esitetty syöte on aluksi todella ennakoivaa eli ohjaa selvästi verkkoa toimimaan halutulla tavalla. Haasteen tähän tuo neuroverkkojen monimutkaiset prosessit, jotka eivät opi aineistojen väliesityksiä, kuten vaikka aineiston tarjoamia tunnistustapoja, vaan neuroverkko sisäistää opetusdatasta vain syötteen ja lopputuloksen. Tämä johtaa siihen, että opetuksessa neuroverkot saattavat alkaa tunnistamaan syöpää vääristä johtolangoista, jolloin niiden puuttuessa kone ei lue ilmiselvää syöpää todellisessa tilanteessa.

Lisäksi eri ominaisuuksien opettaminen kerralla on vaikeaa. Radiologi tunnistaa rinnan kuvasta kalkkeumat, sekä epätavalliset lisääntyneiden tiheyksien kohdat. Tekoäly on vaikea kouluttaa niin, että se osaisi tunnistaa kuvasta sekä kalkkeumat, että lisääntyneet massakeskittymät.

Ison ongelman luo jo mammografiassa käytettävä aineisto, lääketieteelliset kuvat, jotka ovat keinotekoisia ja synteettisiä. Tunnistettavat kohteet ovat hyvin pieniä ja saattavat vaihdella runsaasti, jolloin tekoälyn opetukseen joudutaan sisällyttämään suuri määrä esimerkkejä, jotta se kattaisi vaihtelut.

Lisäksi ongelmia teettävät tapaukset, joita ei opetusdatasta löydy. Tapauksissa, joista radiologi tunnistaisi syövän inhimillisen sopeutuvuuden ansiosta, ei tietokone sitä tee. Tällöin ilmiselvä syöpäkasvain saattaa jäädä huomioimatta vain opetusdatan vajavaisuuden takia. Ennen kuin neuroverkot siirtyisi ainoaksi syöpien lukijaksi, on varmistettava, että opetusdata on tarpeeksi laaja ja voi tunnistaa kaikki tapaukset.

Lisäksi neuroverkolla on myös samanlaisia puutteita kuten CAD:lla kehotusten kanssa, sillä ohjelman ilmoittamat kehotteet tulkitsemastaan kuvasta on vaikea saada ihmisille ymmärrettävään muotoon. [2]

4.5 *Neuroverkot ja mammografian eri kuvausmodaliteetit*

Tomografiakuvat muistuttavat merkittävästi mammogrammeja, jolloin niitä on helppo vertailla keskenään, mutta tekoälylle ne tuovat haasteen. Kuvissa on erot kulma-askeleilla, hankintamekaniikassa, pikseleiden yhdistämisessä, sekä jälleenrakennuksessa. Tämä johtaa kuvien hyvin suuriin eroavaisuuksiin. Etenkin DBT kuvissa kuvien normalisointi on erityisen tärkeää.

Ongelman DBT kuvien lukuun tuo myös niiden kuvajoukkojen pieni määrä, jolloin opetusdata jää pieneksi ja tekoälyn suorituskvyytltä ei voi odottaa samaa kuin 2D

tilanteessa. 2D -mammogrammeista poiketen, on DBT kuvien yhteydessä sovellettu siirto-oppimista, joka soveltuu käyttöön silloin, kun käytössä on vain pieni määrä aineistodataa.

Siirto-oppimisessa käytetään hyödyksi 2D-mammogrammien ja DBT kuvien yhtenäisyyttä ja mammogrammeille opetettua neuroverkkoa sovelletaan DBT kuvien neuroverkkoihin. Nyt siis neuroverkko, joka on opetettu ratkaisemaan haluttu tehtävä suuremmalla määrällä dataa, uudelleen käytetään DBT-kuvien tunnistukseen tarkoitettuun verkkoon, jossa opetusdataa ei ole riittävästi.

DBT-kuvat luovat kuitenkin oman haasteensa tekoälylle, sillä kuvissa on heikko spatiaalinen resoluutio, eli pienimmän erottuvan kohteen koko. Tämä johtaa rajoitettuun tarkkuuteen yhtä anatomista viipaletta kohti ja siten DBT-kuvia lukeva tekoäly on suorituskyvyltään mammogrammeja lukevaa tekoälyä jäljessä. Tomografikuviin perustuvat järjestelmät kuitenkin parantuvat jatkuvasti, kun ihmiset saavat merkattua ja tunnistettua, sekä harjoitusjoukkojen kasvaessa algoritmit tarkentuvat. Tämän avulla voi neuroverkot tulla osaksi tomografiakuvien lukua.

BDT kuvissa on tavallisesti todella pitkä lukuaika, joka pahentaa luonnollisesti radiologien resurssipulaa. Tekoälyn hyödyntäminen leikekuvien tulkinnassa tietokonetomografiakuviin on todella tarpeellinen.

5. Johtopäätökset

Tekoäly ei toistaiseksi vielä voi toimia yksin. Ilman lukijaa toimiakseen täytyy selvittää eettiset ongelmat, sekä tekoälyn päätökset täytyy saada selvennettyä ihmisille ymmärrettävään muotoon. Tulevaisuudessa tekoäly voi kuitenkin mahdollistaa nykyistä enemmän. Lisääntyvä kuvadata, sekä rintasyöpätapauksista, että terveistä rinnoista, mahdollistaa tekoälyn opetuksen ja kehityksen yhä luotettavammaksi lukijaksi. Riittävällä datamäärällä voitaisiin kuvantamiseen integroida myös väestötiedot, syöpien historiat, sekä geneettiset tiedot. Yalan tutkimuksessa näitä tietoja jo hyödynnettiin ja tulokset olivat lupaavia. Näin pystyttäisiin tunnistamaan yhdessä kuvatiedostojen kanssa korkean syöpäriskin omaavat naiset, sekä potilaskohtainen hoito paranisi. On myös ennustettu, että riskiennuste paranee tiheyslaskennan perusteella, kun opetusdata saadaan vain kasvatettua tarpeeksi suureksi.[2]

Teknisten tietojen ja ongelmien ratketessa täytyy kuitenkin selvittää monet poliittiset kysymykset, kuten kuka on vastuussa tilanteista, joissa tapahtuu hoitovirhe, mikäli tekoäly ei tunnista syöpää.

Sekä eettisten, poliittisten, että teknisten ongelmien ratketessa tekoäly pystyy parhaimmillaan integroitumaan moneen, ja monet resurssipulaongelmat ratkeavat syöpien tunnistettavuuden yhä parantuessa. Vielä on kuitenkin mahdotonta sanoa tekoälyn lopullisesta ja todellisesta vaikutuksesta kliiniseen suorituskyykyyn, sekä potilaiden tuloksiin, sillä tietoa ei ole vielä tarpeeksi. [2]

6. Lähteet

- [1] Anttila, A., Heinävaara, S., Sarkeala, T. (10.6.2021). Syöpäseulonnat.
URL: <https://www.syopajarjestot.fi/julkaisut/raportit/syopa-suomessa-2016/syopaseulonnat/>.
- [2] Geras, K. J., Mann, R. M., & Moy, L. (2019). Artificial Intelligence for Mammography and Digital Breast Tomosynthesis: Current Concepts and Future Perspectives Radiology, 293(2), 246–259.
DOI: <https://doi.org/10.1148/radiol.2019182627>.
- [3] Joensuu, H., Aalberg, V., Roberts, P. J., Kellokumpu-Lehtinen, P., Jyrkkiö, S., Kouri, M. & Teppo, L. (2013). Syöpätaudit (5. uud. p.). Duodecim.
- [4] Tapiovaara, M., Miettinen, A., Sipilä, P., Korpela, H., Väisälä, S., Kaituri, M. & Pukkila, O. (2004). Säteilyn käyttö. Säteilyturvakeskus.
- [5] Jesinger, R.A. (2014). Breast anatomy for the interventionalist. Techniques in vascular and interventional Radiology. 17(1):3-9. DOI: <https://doi.org/10.1053/j.tvir.2013.12.002>.
- [6] Vehmanen, L. (2020). Rintasyövän toteaminen, alatyypit ja ennuste. Lääkärikirja Duodecim.
- [7] Alanko, J. (2019) Rintasyöpäseulonnan nykytilanne ja kuvantamisen uudet mahdollisuudet. Lääketieteellinen aikakausikirja Duodecim. 135(19):1904-11.
URL: <https://www.duodecimlehti.fi/duo15149>.
- [8] Rissanen, T. & Dean, P.B. (2017) Rinnan kuvantamismenetelmien perusteet ja käyttöalueet. Kliininen radiologia.
- [9] Rissanen, T. & Dean, P.B. (2017). Rinnat. Kliininen radiologia.
- [10] Paajanen, H., Lehtonen, M., Hermunen, H., Helle, M. & Dean, P.B. (2005). Seulonnan merkitys rintasyövän toteamisessa. Lääkärilehti. 21/2005, vsk 60, s. 2319-2323. URL
: <https://www.laakarilehti.fi/tieteessa/alkuperaistutkimukset/seulonnan-merkitys-rintasyovan-toteamisessa/>.
- [11] Huhtanen, H., Nyman, M., Karlsson, A. & Hirvonen, J. (2020) Tekoäly radiologiassa. Lääketieteellinen aikakausikirja Duodecim. 136(17):1957 -64.
- [12] Nieminen, M. Röntgensäteilyyn perustuvat menetelmät. (2017.) Kliininen radiologia.
- [13] Wu, N. et al. (2018). "Breast density classification with deep convolutional neural networks," 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pp. 6682-6686 DOI: 10.1109/ICASSP.2018.8462671.
- [14] Wu, N. et al. (2020). "Deep neural networks improve radiologists' performance in breast cancer screening," in IEEE Transactions on Medical Imaging, vol. 39, no. 4, pp. 1184-1194, DOI: 10.1109/TMI.2019.2945514.

- [15] Yala, A. et al. (2021). "Toward robust mammography-based models for breast cancer risk," in AAAS Science Translational Medicine. Vol. 13, Issue 578, eaba4373, DOI: 10.1126/scitranslmed.aba4373.
- [16] Haykin, S. (2009). Neural networks and learning machines (3rd ed.). Pearson.
- [17] Chung, H., Lee, S.J. & Park, J.G. (2016). Deep neural network using trainable activation functions. 2016 International Joint Conference on Neural Networks (IJCNN). 2016:348-352. DOI: 10.1109/IJCNN.2016.7727219.
- [18] Barzilay, R. & Yala, A. (10.6.2021). "Robust AI tools to predict future cancer", in CSAIL MIT Computer Science & Artificial Intelligence Lab, Jan 2021. URL : <https://www.csail.mit.edu/news/robust-ai-tools-predict-future-cancer>.